

BAB I

PENDAHULUAN

1.1. Latar Belakang

Gaya belajar menggambarkan sikap dan perilaku peserta didik dalam memahami dan memproses informasi, yang menjadi aspek penting dalam sistem pendidikan. Gaya belajar tidak hanya membantu peserta didik memahami kekuatan dan kelemahan mereka, tetapi juga membantu pengajar dalam menyusun strategi pembelajaran yang lebih efektif. Menurut Graf et al. (2008), kurangnya dukungan terhadap gaya belajar peserta didik oleh sistem pembelajaran dapat menjadi salah satu faktor penyebab kegagalan dalam proses pembelajaran. Oleh karena itu, mempertimbangkan gaya belajar dalam proses pembelajaran dapat meningkatkan efisiensi belajar peserta didik.

Pendekatan tradisional dalam mengidentifikasi gaya belajar, seperti kuesioner, masih menghadapi banyak kritik, meskipun memiliki validitas dan reliabilitas yang baik. Mengisi kuesioner dapat menjadi tugas yang membosankan bagi peserta didik, terutama jika instrumen memiliki lebih dari 100 item. Selain itu, peserta didik cenderung memberikan jawaban asal-asalan jika mereka tidak menyadari pentingnya kuesioner tersebut. Kuesioner juga berasumsi bahwa peserta didik menyadari preferensi belajar mereka, meskipun kenyataannya sering kali tidak demikian. Pendekatan kuesioner bersifat statis, sementara gaya belajar peserta didik dapat berubah seiring waktu, sehingga hasil kuesioner menjadi tidak valid ketika terjadi perubahan preferensi belajar (Feldman et al., 2015).

Perkembangan platform pembelajaran seperti Learning Management System (LMS) memberikan peluang untuk mendeteksi gaya belajar secara dinamis. Saat ini terdapat lebih dari 70 model gaya belajar yang telah diusulkan, dengan beberapa di antaranya merupakan kombinasi atau modifikasi dari model lain. Di antara model-model tersebut, Felder-Silverman Learning Style Model (FSLSM) menjadi salah satu yang paling sering digunakan untuk mendeteksi gaya belajar peserta didik secara otomatis. FSLSM dianggap lebih unggul karena memberikan deskripsi gaya belajar yang lebih detail dengan validitas dan reliabilitas yang terbukti. Selain itu, instrumen yang dirancang berdasarkan FSLSM mudah digunakan karena hanya terdiri dari dua pilihan berlawanan untuk setiap dimensi (Li & Abdul Rahman, 2018; Feldman et al., 2015).

Pendekatan untuk mendeteksi gaya belajar secara otomatis terbagi menjadi dua, yaitu pendekatan berbasis literatur dan pendekatan berbasis data. Pendekatan berbasis literatur menggunakan aturan sederhana untuk menghitung preferensi gaya belajar berdasarkan petunjuk yang tersedia dari model

pengguna. Meskipun generik dan dapat diterapkan di berbagai kelas pembelajaran, pendekatan ini memiliki kelemahan dalam memperkirakan bobot pentingnya petunjuk tersebut. Sebaliknya, pendekatan berbasis data menggunakan algoritma kecerdasan buatan untuk mengklasifikasikan gaya belajar berdasarkan data riil. Pendekatan ini lebih akurat tetapi sangat bergantung pada ketersediaan dataset representatif untuk membangun model klasifikasi yang andal (Graf, 2007). Perbedaan yang paling mendasar pada kedua pendekatan ini adalah pada tahap *labelling*. Pendekatan berbasis literatur melabelkan data dengan memetakan setiap fitur yang bersesuaian dengan gaya belajar peserta didik, sedangkan label data pada pendekatan berbasis data diperoleh dari kuisioner ILS (*Index of Learning Styles*).

Pendekatan berbasis data khususnya untuk mendeteksi FSLSM menjadi semakin dominan seiring dengan kemajuan teknologi pembelajaran mesin dan analisis data yang lebih kompleks. Pada pendekatan ini, berbagai teknik telah diterapkan, mulai dari *Decision Tree*, *Bayesian Network*, *K-Nearest Neighbors*, *Random Forest*, dan *Support Vector Machine*.

Karagiannis dan Satratzemi (2017) mengembangkan mekanisme adaptif pada Moodle untuk mendeteksi gaya belajar secara otomatis. Penelitian lain oleh Kika et al. (2019) menggunakan teknik *Decision Tree* pada data Moodle untuk mengklasifikasikan gaya belajar mahasiswa, sementara Sheeba dan Krishnan (2019) memanfaatkan *Decision Tree* untuk mendeteksi gaya belajar mahasiswa dalam sistem pembelajaran berbasis LMS. Harun (2020) melanjutkan tren ini dengan menganalisis perilaku mahasiswa untuk mendeteksi gaya belajar mereka melalui platform Moodle. Penelitian lain menggunakan Bayesian Network untuk mendeteksi gaya belajar dalam sistem *e-learning adaptif* (Mahnane dan Hafidi, 2016). Liyanage et al. (2016) juga memanfaatkan Bayesian Network dalam mendeteksi gaya belajar mahasiswa dalam lingkungan LMS.

Penelitian tentang deteksi otomatis FSLSM kemudian berkembang menjadi kombinasi beberapa teknik *machine learning*. Aissaoui et al. (2018) memperkenalkan pendekatan hibrida yang menggabungkan algoritma *supervised* dan *unsupervised machine learning* untuk memprediksi gaya belajar. Pada tahun berikutnya, Aissaoui et al. (2019) melanjutkan dengan mengombinasikan Naïve Bayes dan algoritma K-modes untuk meningkatkan deteksi gaya belajar. Hidayat et al. (2020) juga berkontribusi dalam peningkatan model deteksi dengan menggabungkan algoritma K-Means yang dimodifikasi dengan Naïve Bayesian.

Di sisi lain, penelitian berbasis literatur memiliki pondasi kuat dalam studi Dung dan Florea (2012), yang mengusulkan metode berbasis literatur untuk mendeteksi gaya belajar secara otomatis dalam LMS. Ahmad et al. (2013) juga menerapkan metode ini dalam Moodle, sementara Amir et al. (2016) menggabungkan pendekatan berbasis literatur dengan Mesin Vektor Pendukung (MVP) atau Support Vector Machine (SVM) untuk meningkatkan akurasi deteksi.

Pada artikel ini, Amir et al. (2016) membandingkan akurasi antara SVM dan Naïve Bayes, yang menunjukkan akurasi SVM lebih tinggi daripada Naïve Bayes. Mehenaoui et al. (2022) juga menunjukkan keunggulan SVM dibandingkan dengan teknik *machine learning* yang lain.

Sebagian besar penelitian yang telah diuraikan sebelumnya menggunakan data pada skala lokal dan cenderung memiliki karakteristik yang homogen, seperti mahasiswa ilmu komputer (Karagiannis dan Satratzemi, 2017; Dung dan Florea, 2012; Amir et al., 2016)), mahasiswa jurusan anatomi (Mahnane dan Hafidi, 2016), atau mahasiswa program profesi guru pada mata pelajaran matematika dan biologi (Hidayat et al., 2020). Obyek penelitian juga berjumlah kurang dari 300 siswa/mahasiswa. Keterbatasan dalam skala dan keragaman data ini menjadi tantangan dalam mengembangkan model deteksi gaya belajar yang mampu mencerminkan dinamika pembelajaran yang lebih luas. Penelitian dengan cakupan lokal sering kali menghasilkan model yang teradaptasi dengan baik pada kelompok tertentu, tetapi kurang mampu diimplementasikan secara general untuk populasi yang lebih besar dan beragam.

Penelitian ini mencoba menjawab tantangan tersebut dengan memanfaatkan data dari LMS-SPADA (Sistem Pembelajaran Daring), platform pembelajaran daring nasional yang dikelola oleh Kementerian Pendidikan, Kebudayaan, Riset, dan Teknologi (Kemendikbudristek). LMS-SPADA menghubungkan berbagai perguruan tinggi di Indonesia dan melayani mahasiswa dari beragam disiplin ilmu, memungkinkan akses pembelajaran yang luas dan terintegrasi. Data dari LMS-SPADA mencerminkan pola pembelajaran yang heterogen, mencakup variasi dalam latar belakang mahasiswa, mata pelajaran, dan metode pembelajaran. Hal ini memberikan peluang untuk mengembangkan model deteksi gaya belajar yang lebih general dan akurat dibandingkan model berbasis data lokal. Dengan jangkauan nasional dan skala besar, LMS-SPADA menjadi sumber data ideal untuk membangun sistem pembelajaran adaptif yang inklusif dan mendukung personalisasi pendidikan.

Namun, beberapa fitur penting untuk mendeteksi gaya belajar berdasarkan FSLSM belum tersedia langsung di LMS-SPADA. Untuk mengatasi keterbatasan ini, diperlukan agregasi fitur dari data yang ada, seperti pola akses materi, interaksi dalam diskusi, dan hasil evaluasi. Pendekatan ini memungkinkan pengolahan data menjadi indikator baru yang relevan dengan FSLSM, sehingga mendukung pengembangan model deteksi yang lebih akurat tanpa perlu modifikasi besar pada sistem SPADA.

Penelitian ini juga mengintegrasikan algoritma *Support Vector Machine* (SVM) dengan teknik *Recursive Feature Elimination* (RFE) untuk lebih meningkatkan akurasi model deteksi,. SVM merupakan algoritma pembelajaran mesin yang andal dalam klasifikasi data, khususnya dalam menangani dataset yang kompleks (Mahenaoui, 2022). Namun, ketika digunakan pada data berskala besar dengan banyak fitur seperti data LMS-SPADA, SVM dapat mengalami

penurunan akurasi akibat kehadiran fitur yang tidak relevan atau redundan. RFE diterapkan sebagai metode seleksi fitur iteratif yang bertujuan menghilangkan fitur-fitur dengan kontribusi rendah, sehingga menghasilkan subset fitur yang optimal untuk meningkatkan performa model (Huang et. al., 2014). Selain mengurangi dimensi data, Integrasi SVM-RFE juga dapat meningkatkan efisiensi dan akurasi model dalam mendeteksi gaya belajar mahasiswa dari data yang heterogen. Dengan pendekatan ini, model deteksi dapat lebih adaptif terhadap pola pembelajaran yang berbeda-beda di seluruh institusi yang terhubung melalui LMS-SPADA.

1.2. Rumusan Masalah

LMS-SPADA sebagai platform pembelajaran daring nasional di Indonesia memiliki potensi besar dalam mendukung personalisasi pembelajaran melalui deteksi gaya belajar mahasiswa. Namun, keterbatasan dalam fitur yang secara spesifik dibutuhkan untuk mendeteksi gaya belajar berbasis Felder-Silverman Learning Style Model (FSLSM) menjadi tantangan tersendiri. Fitur-fitur ini sering kali tidak tersedia secara langsung dalam sistem, mengingat LMS SPADA lebih berfokus pada manajemen dan distribusi konten pembelajaran.

Pada konteks ini, pendekatan agregasi fitur dari data aktivitas mahasiswa yang sudah tersedia menjadi alternatif yang menjanjikan. Data seperti pola akses materi, partisipasi diskusi, dan hasil evaluasi dapat diolah untuk menghasilkan indikator yang relevan dengan dimensi FSLSM. Namun, belum ada metode yang teruji secara komprehensif dalam mengintegrasikan dan mengoptimalkan data tersebut untuk mendeteksi gaya belajar mahasiswa secara akurat dan adaptif dalam skala besar.

Dengan demikian, pertanyaan utama yang muncul adalah sebagai berikut:

1. Bagaimana mengatasi keterbatasan fitur pada LMS-SPADA agar relevan dengan dimensi FSLSM?
2. Bagaimana performa SVM dibandingkan teknik *machine learning* lainnya dalam klasifikasi gaya belajar mahasiswa?
3. Bagaimana meningkatkan akurasi SVM dalam klasifikasi gaya belajar mahasiswa?

1.3. Tujuan Penelitian

Berdasarkan rumusan masalah yang telah diuraikan, maka tujuan yang ingin dicapai adalah:

1. Melakukan analisis untuk mengatasi keterbatasan fitur pada LMS-SPADA agar relevan dengan dimensi FSLSM;

2. Menganalisis performa SVM dibandingkan dengan teknik *machine learning* yang lain;
3. Menganalisis performa metode MVP untuk klasifikasi gaya belajar peserta didik dibandingkan dengan metode *machine learning* lainnya;
4. Mengembangkan metode MVP untuk akurasi yang lebih tinggi pada data log dari LMS SPADA.

1.4. Kegunaan Penelitian

Penelitian ini memiliki manfaat signifikan dalam mendeteksi gaya belajar peserta didik secara otomatis menggunakan data dari Learning Management System (LMS), sehingga mengurangi ketergantungan pada survei manual yang memakan waktu dan rentan terhadap kesalahan. Dengan memanfaatkan algoritma SVM-RFE, penelitian ini meningkatkan efisiensi seleksi fitur dan menghasilkan model yang akurat serta hemat waktu. Pendekatan ini memungkinkan personalisasi pembelajaran yang lebih baik dengan menyesuaikan konten dan metode pengajaran sesuai dengan gaya belajar individu, yang pada akhirnya meningkatkan motivasi dan hasil belajar peserta didik.

Selain itu, penelitian ini menawarkan kontribusi dalam pemanfaatan teknologi pendidikan dengan memanfaatkan data aktivitas peserta didik secara efektif untuk menganalisis perilaku belajar. Dengan demikian, pendekatan ini dapat diterapkan pada skala besar untuk mendukung pembelajaran daring yang lebih adaptif dan responsif. Secara akademis, penelitian ini memberikan kontribusi metodologis melalui pengembangan model deteksi gaya belajar berbasis indikator FLSM, memperkaya literatur tentang *educational data mining* dan *machine learning* dalam pendidikan. Sebagai implementasi, penelitian ini membuka peluang untuk diterapkan dalam berbagai LMS dan konteks pendidikan global, sekaligus mendukung institusi pendidikan dalam merancang kebijakan berbasis data untuk meningkatkan kualitas dan efisiensi sistem pembelajaran.

1.5. Ruang Lingkup Penelitian

Berdasarkan latar belakang yang telah dikemukakan sebelumnya, maka perlu diberikan batasan belakang masalah dalam penelitian ini, sebagai berikut:

1. Penelitian ini berfokus pada pengembangan metode otomatis untuk mendeteksi gaya belajar siswa dengan memanfaatkan data aktivitas dari Learning Management System (LMS), khususnya yang tersedia di platform LMS-SPADA. Model yang digunakan berbasis Felder-Silverman Learning

Style Model (FSLSM) dengan empat dimensi utama, yaitu *Processing*, *Perception*, *Input*, dan *Understanding*.

2. Data yang diolah mencakup fitur-fitur yang tersedia di LMS-SPADA, baik dalam bentuk fitur langsung maupun fitur sintetis yang dihasilkan melalui agregasi atribut yang relevan.
3. Pendekatan algoritma *Support Vector Machine* dengan *Recursive Feature Elimination* (SVM-RFE) digunakan untuk meningkatkan akurasi dan efisiensi dalam mendeteksi gaya belajar.

1.6. Kebaruan Penelitian

Penelitian ini menghadirkan pendekatan agregasi fitur dalam mendeteksi gaya belajar menggunakan LMS SPADA, yang mencakup skala nasional dan beragam latar belakang mahasiswa. Pendekatan ini berbeda dari penelitian sebelumnya yang cenderung menggunakan data lokal dan terbatas pada satu institusi atau mata kuliah tertentu.

Penelitian ini juga mengintegrasikan berbagai aktivitas online dan indikator model Felder-Silverman (FSLSM) yang tersedia dalam LMS, menghasilkan fitur-fitur baru melalui proses agregasi. Hal ini memungkinkan deteksi gaya belajar yang lebih akurat meskipun beberapa fitur spesifik FSLSM tidak tersedia langsung dalam SPADA. Dengan demikian, penelitian ini memperkenalkan metode optimalisasi deteksi gaya belajar melalui analisis komparatif berbagai algoritma *machine learning*, yang memberikan kontribusi signifikan terhadap pengembangan sistem pembelajaran adaptif berbasis data besar (big data) di tingkat nasional.

Pendekatan ini tidak hanya meningkatkan akurasi prediksi gaya belajar, tetapi juga memperluas penerapan model deteksi dalam lingkungan pembelajaran yang lebih heterogen dan inklusif, menjadikannya sebagai inovasi dalam upaya personalisasi pembelajaran daring di Indonesia.

1.7. Teori

Pemahaman yang komprehensif terhadap penelitian ini memerlukan penjabaran teori-teori yang mendasari pengembangan model deteksi otomatis gaya belajar. Konsep utama yang menjadi landasan adalah Felder-Silverman Learning Style Model (FSLSM), yang digunakan sebagai kerangka dalam mengidentifikasi preferensi belajar mahasiswa. Pendekatan pembelajaran mesin berperan penting dalam mendukung deteksi otomatis, dengan fokus pada algoritma Support Vector Machine (SVM).

1.7.1. Gaya belajar Felder-Silverman

Model gaya belajar Felder-Silverman mengklasifikasikan gaya belajar siswa berdasarkan empat dimensi, masing-masing dengan dua kategori yang saling bertentangan. Ciri-ciri masing-masing gaya belajar dapat dilihat pada tabel 1.1.

Tabel 1.1. Indikator Gaya belajar Felder-Silverman

Dimensi	Gaya Belajar	Sifat
<i>Processing</i> (menunjukkan bagaimana mahasiswa memproses informasi)	<i>Aktif</i>	Lebih suka interaksi aktif melalui diskusi, latihan, dan kerja kelompok. Pahami materi dengan baik saat terlibat dalam kegiatan fisik atau kolaboratif.
	<i>Reflektif</i>	Lebih suka merefleksikan dan menganalisis informasi secara individual. Pahami informasi setelah berpikir secara mendalam dalam konteks yang tenang.
<i>Perception</i> (mengukur bagaimana mahasiswa lebih nyaman menerima informasi)	<i>Sensing</i>	Lebih menyukai fakta, data, dan contoh nyata. Lebih nyaman dengan hal yang konkrit, detail, serta praktis.
	<i>Intuitif</i>	Menyukai teori dan konsep abstrak. Tertarik pada gambaran besar dan ide-ide baru, serta materi yang bersifat konseptual.
<i>Input</i> (menunjukkan penyajian informasi yang bagaimana yang lebih disukai)	<i>Visual</i>	Belajar lebih baik melalui gambar, diagram, grafik, video, dan demonstrasi visual lainnya. Pahami informasi visual lebih baik daripada teks.
	<i>Verbal</i>	Menyukai penjelasan dalam bentuk teks atau lisan. Belajar dengan baik melalui membaca, diskusi, dan instruksi verbal.

Lanjutan Tabel 1.1.

<i>Understanding</i> (menunjukkan bagaimana mahasiswa memahami dan mengatur informasi)	<i>Sequential</i>	Belajar secara sistematis, selangkah demi selangkah dalam urutan yang logis. Memahami materi yang disusun secara berkesinambungan.
	<i>Global</i>	Belajar dengan melihat seluruh konteks terlebih dahulu dan memahami informasi secara acak atau melompat-lompat. Menghubungkan konsep secara holistik.

Sumber: Felder & Silverman (1988)

1.7.2. Fitur gaya belajar Felder-Silverman

Perilaku online siswa yang direkam di LMS, yang dapat digunakan untuk mendeteksi gaya belajar model Felder Silverman, dapat dilihat pada tabel 1.2.

Tabel 1.2. Fitur gaya belajar Felder-Silverman

No.	Fitur	Informasi		Gaya Belajar yang Terdeteksi	Dimensi
1.	<i>Content Visit</i>	Jumlah konten pembelajaran yang dikunjungi oleh siswa	konten yang	<i>Active /Reflective, Sensing/ Intuitive, Visual/ Verbal,</i>	<i>Processing, Perception, Input</i>
2.	<i>Content Stay</i>	Waktu yang dihabiskan oleh siswa dalam konten pembelajaran	konten	<i>Active /Reflective, Sensing/ Intuitive</i>	<i>Processing, Perception</i>
3.	<i>Outline Visit</i>	Menggambarkan berapa kali siswa mengunjungi struktur materi pembelajaran	materi	<i>Sequential/ Global</i>	<i>Understanding</i>

Lanjutan Tabel 1.2.

No.	Fitur	Informasi	Gaya Belajar yang Terdeteksi	Dimensi
4.	<i>Outline Stay</i>	Mengukur total waktu yang dihabiskan siswa pada bagian materi pembelajaran	<i>Active /Reflective</i>	<i>Processing</i>
5.	<i>Example Visit</i>	Jumlah kunjungan ke bagian contoh atau studi kasus dalam materi	<i>Sensing/ Intuitive</i>	<i>Perception</i>
6.	<i>Example Stay</i>	Total waktu yang dihabiskan untuk mempelajari contoh	<i>Active /Reflective, Sensing/ Intuitive</i>	<i>Processing, Perception</i>
7.	<i>Self-Assesment Visit</i>	Frekuensi siswa mengunjungi bagian penilaian mandiri	<i>Active /Reflective, Sensing/ Intuitive</i>	<i>Processing, Perception</i>
8.	<i>Self-Assesment Stay</i>	Total waktu yang dihabiskan siswa dalam penilaian mandiri	<i>Active /Reflective, Sensing/ Intuitive</i>	<i>Processing, Perception</i>
9.	<i>Self-Assesment Twice Wrong</i>	Frekuensi siswa salah menjawab dua kali berturut-turut dalam penilaian mandiri	<i>Active /Reflective</i>	<i>Processing</i>
10.	<i>Exercise Visit</i>	Jumlah tugas yang dikunjungi oleh siswa	<i>Active/ Reflective, Sensing /Intuitive</i>	<i>Processing, Perception</i>
11.	<i>Exercise Stay</i>	Waktu yang dihabiskan oleh siswa mengerjakan tugas	<i>Active /Reflective</i>	
12.	<i>Question Detail Points</i>	<i>Poin Detail Soal</i> adalah fitur yang menggambarkan nilai yang diberikan kepada siswa dalam memecahkan masalah (soal) yang diasumsikan secara detail.	<i>Sensing/ Intuitive, Sequential/ Global</i>	<i>Perception, Understanding</i>

Lanjutan Tabel 1.2.

No.	Fitur	Informasi	Gaya Belajar yang Terdeteksi	Dimensi
13.	<i>Question Overview Points</i>	<i>Poin Tinjauan Pertanyaan</i> adalah fitur yang menggambarkan nilai yang diberikan kepada siswa dalam memecahkan masalah (pertanyaan) yang diasumsikan secara ikhtisar.	<i>Sequential/ Global</i>	<i>Understanding</i>
14.	<i>Question Facts Points</i>	<i>Poin Fakta Pertanyaan</i> adalah fitur yang menggambarkan nilai yang diberikan kepada siswa dalam memecahkan masalah (pertanyaan) yang diasumsikan berdasarkan fakta.	<i>Sensing /Intuitive</i>	<i>Perception</i>
15.	<i>Question Concepts Points</i>	<i>Poin Konsep Pertanyaan</i> adalah fitur yang menggambarkan nilai yang diberikan kepada siswa dalam memecahkan masalah (soal) yang diasumsikan berdasarkan konsep.	<i>Sensing /Intuitive</i>	<i>Perception</i>
16.	<i>Question Graphics Points</i>	<i>Question Graphics Point</i> merupakan fitur yang menggambarkan nilai yang diberikan kepada siswa dalam memecahkan masalah (soal) yang diasumsikan berupa visual/gambar/video.	<i>Active/ Reflective, Visual/ Verbal</i>	<i>Processing, Input</i>

Lanjutan Tabel 1.2.

No.	Fitur	Informasi	Gaya Belajar yang Terdeteksi	Dimensi
17.	<i>Question Text Points</i>	<i>Poin Teks Pertanyaan</i> adalah fitur yang menggambarkan nilai yang diberikan kepada siswa dalam memecahkan masalah (soal) yang diasumsikan berupa teks.	<i>Active /Reflective, Visual/ Verbal</i>	<i>Processing, Input</i>
18.	<i>Question Interpret Points</i>	<i>Poin yang diberikan berdasarkan kemampuan siswa memahami pertanyaan</i>	<i>Sequential/ Global</i>	<i>Understanding</i>
19.	<i>Question Develop Points</i>	<i>Poin yang diberikan berdasarkan kemampuan siswa mengembangkan jawaban</i>	<i>Sensing/ Intuitive, Sequential/ Global</i>	<i>Perception, Global</i>
20.	<i>Quiz Revisions</i>	Jumlah kuis yang direvisi oleh siswa	<i>Sensing/ Intuitive</i>	<i>Perception</i>
21.	<i>Quiz Stay Result</i>	Waktu yang dihabiskan siswa pada kuis dan hasil yang diperoleh	<i>Active/ Reflective, Sensing/ Intuitive</i>	<i>Processing, Perception</i>
22.	<i>Forums Visit</i>	Jumlah forum diskusi yang dikunjungi oleh mahasiswa	<i>Active/ Reflective, Visual/ Verbal</i>	<i>Processing, Input</i>
23.	<i>Forum Post</i>	Jumlah diskusi yang dilakukan oleh mahasiswa dalam sebuah forum	<i>Active /Reflective, Visual/ Verbal</i>	<i>Processing, Input</i>
24.	<i>Forum Stay</i>	Waktu yang dihabiskan oleh siswa di sebuah forum.	<i>Visual/ Verbal</i>	<i>Input</i>
25.	<i>Navigation Skip</i>	Mengukur berapa kali siswa melewati atau melompati bagian materi	<i>Sequential/ Global</i>	<i>Understanding</i>

Lanjutan Tabel 1.2.

No.	Fitur	Informasi			Gaya Belajar yang Terdeteksi	Dimensi
26.	<i>Navigation Overview Visit</i>	Frekuensi mengunjungi gambaran ringkasan	siswa bagian umum atau		<i>Sequential/ Global</i>	<i>Understanding</i>
27.	<i>Navigation Overview Stay</i>	Total waktu yang dihabiskan pada ringkasan	bagian		<i>Sequential/ Global</i>	<i>Understanding</i>

Sumber: Graf & Liu (2008)

1.7.3. Support Vector Machine

Support Vector Machine (Cortes & Vapnik, 1995) dapat digunakan untuk regresi tiga jenis hasil yang berbeda: Bernoulli (biner), multinomial, atau kontinu. Regresi dengan hasil Bernoulli sering disebut sebagai klasifikasi dalam pembelajaran statistik. Regresi dengan hasil multinomial disebut klasifikasi multiclass. Akhirnya, regresi dengan hasil kontinu disebut regresi.

Gambar 1.1 memberikan contoh dengan dua variabel bebas. Hasilnya, keanggotaan kelas ($y = 1$ atau $y = -1$), ditunjukkan dengan simbol yang berbeda dalam plot. Dapat digambarkan banyak garis yang memisahkan kedua kelas, dua di antaranya ditunjukkan pada Gambar 1.1. Manakah dari mereka yang "terbaik"? Salah satu pilihan yang masuk akal adalah memilih garis pemisah sedemikian rupa sehingga margin, dalam hal ini, jarak minimum antara garis dan titik terdekat dimaksimalkan. Hal ini mengarah ke masalah optimasi berikut: (Guenther & Schonlau, 2016)

$$\underset{\beta_j, j=1,2,\dots,p}{\text{maximize}} M \quad (1)$$

$$\text{subject to} \begin{cases} \sum_{j=1}^p \beta_j^2 = 1 \\ y_i(\beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip}) \geq M \end{cases} \quad (2)$$

di mana M adalah margin, p adalah jumlah variabel x , dan $y_i \in \{-1, 1\}$, $i = 1, \dots, n$. Baris kedua dalam Persamaan (1) mewakili *hyperplane*. Dalam dua dimensi, seperti pada Gambar 1.1, *hyperplane* adalah garis. Pengamatan bagian atas *hyperplane* memenuhi:

$$(\beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip}) > 0$$

dan pengamatan pada bagian bawah *hyperplane* memenuhi:

$$(\beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip}) < 0$$

Pengamatan pada bagian bawah *hyperplane* memiliki label kelas -1 , sehingga:


$$y(\beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip})$$

selalu bernilai positif selama kedua kelas dapat dipisahkan. Kenyamanan matematis ini adalah alasan mengapa label kelas adalah $\{-1,1\}$ digunakan daripada label tipikal, $\{0,1\}$, yang digunakan dalam regresi logistik. Batasan pada β_j pada Persamaan (1) tidak diperlukan, namun memiliki keuntungan bahwa jarak pengamatan i ke *hyperplane* sama dengan:

$$y(\beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip})$$

ketika β_j diskalakan sedemikian rupa sehingga kendalanya berlaku.

Masalah optimasi pada Persamaan (1) dan (2) dapat diselesaikan dengan pemecah program kuadrat (*quadratic program solver*). Yang penting, solusinya hanya bergantung pada pengamatan yang terletak pada margin. Hal ini sangat mengurangi komputasi karena hanya sebagian kecil dari data yang diperlukan untuk menghitung solusi optimal. Subset pengamatan itu disebut vektor pendukung (*support vector*). Contoh pada Gambar 1.1 memiliki tiga vektor pendukung.




Gambar 1.1. Plot SVM dengan 2 kelas (1)

Pada sebagian besar aplikasi, kedua kelas tidak dapat dipisahkan, dan masalah optimasi tidak memiliki solusi. Ini dapat diatasi dengan mengizinkan sejumlah kesalahan: (Guenther & Schonlau, 2016)

$$\underset{\beta_{ij}, \epsilon_i, l=1, \dots, n; j=1, 2, \dots, p}{\text{maximize}} \quad M \quad (3)$$

$$\text{subject to} \quad \begin{cases} \sum_{j=1}^p \beta_j^2 = 1 \\ y_i(\beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip}) \geq M \\ \epsilon_i \geq 0; \sum_{i=1}^n \epsilon_i \leq C \end{cases} \quad (4)$$

Dengan adanya *slack variables*, ϵ_i , memungkinkan pengamatan terletak pada sisi margin yang salah. Namun, jumlah kesalahan tersebut tidak dapat melebihi *total error rate*, C .



Gambar 1.2. Plot SVM dengan 2 kelas (2)

Perlu diingat kembali bahwa solusi untuk masalah optimasi hanya bergantung pada vektor pendukung (*support vector*): pengamatan yang terletak pada margin atau pengamatan yang melanggar margin. Perhatikan contoh pada Gambar 1.2. Garis tebal memisahkan sebagian besar segitiga dan bujur sangkar, kecuali satu bujur sangkar di atas garis dan satu segitiga di bawah garis (keduanya dilingkari). Garis putus-putus atas adalah margin untuk segitiga, dan garis putus-putus bawah adalah margin untuk kotak. Seperti sebelumnya, ada beberapa pengamatan langsung di margin. Tidak seperti sebelumnya, ada juga

pengamatan yang melanggar margin. Pengamatan yang melanggar margin tidak salah diklasifikasikan selama mereka terletak di sisi yang benar dari batas keputusan. Perhatikan salah satu pengamatan yang salah diklasifikasikan, persegi, muncul di luar dua margin. Bagaimanapun itu merupakan vektor pendukung karena melanggar margin yang lebih rendah. Pelanggarannya begitu besar sehingga melampaui batas atas.

Nilai C yang besar meningkatkan penalti untuk kesalahan klasifikasi pada data latih. Hal ini sesuai dengan margin yang lebih ketat. Nilai C yang besar juga sesuai dengan vektor pendukung yang lebih sedikit karena lebih sedikit pengamatan yang salah diklasifikasikan dan karena lebih sedikit pengamatan yang berada dalam margin yang lebih ketat. Gambar 1.2 menunjukkan SVM dengan nilai C yang cukup besar (10.000). Jumlah pengamatan yang salah klasifikasi (dalam data latih) diminimalkan. Meminimalkan jumlah kesalahan klasifikasi dalam pelatihan dapat mengakibatkan overfitting di mana kinerja yang buruk terjadi pada data uji. Nilai C disebut sebagai parameter penyetelan (-tuning). Secara matematis, klasifikasi untuk dua kelas y didasarkan pada $\text{sign}\{\hat{f}(x)\}$ (yaitu, sisi *hyperplane* mana pengamatan berada) dengan: (Guenther & Schonlau, 2016)

$$\begin{aligned}\hat{f}(x) &= \hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \dots + \hat{\beta}_p x_{ip} \\ &= \hat{\beta}_0 + \sum_{i \in S} \hat{\alpha}_i y_i \langle x, x_i \rangle\end{aligned}\quad (5)$$

di mana $\hat{\alpha}_i > 0$ adalah koefisien estimasi yang muncul selama optimasi, S adalah himpunan vektor pendukung, dan $\langle \dots, \dots \rangle$ adalah perkalian dalam (titik). Hasil kali titik adalah ukuran kemiripan antara dua pengamatan $i \in \{1, \dots, n\}$ dan $i' \in \{1, \dots, n\}$. Hal ini disebut perkalian dalam (*inner product*) K atau disebut juga dengan kernel linier:

$$K(x_i, x_{i'}) = \langle x_i, x_{i'} \rangle = \sum_{j=1}^p x_{ij} x_{i'j} \quad (6)$$

Terkadang dalam sebuah kasus perlu menambahkan variabel tambahan sebagai fungsi dari variabel asli, seperti variabel polinomial. Variabel polinomial meningkatkan jumlah variabel yang tersedia untuk regresi, tetapi jumlah variabel x yang mendasarinya tetap tidak berubah. Variabel tersebut juga dapat ditambahkan dalam SVM. Menambahkan variabel tidak mengubah masalah optimasi dalam persamaan (3) dan (4).

Misalkan definisikan $h(x_i) = \{h_1(x_i), h_2(x_i), \dots, h_p(x_i)\}$ untuk $i = 1, \dots, n$. Misalnya, syarat kuadrat untuk x_1 dari pengamatan i dapat ditambahkan dengan menentukan $h(x_i) = (x_{i1}, x_{i2}, \dots, x_{ip}, x_{i1}^2)$. Persamaan (5) berubah menjadi:

$$\begin{aligned}\hat{f}(x) &= \hat{\beta}_0 + \hat{\beta}_1 h(x_{i1}) + \dots + \hat{\beta}_p h(x_{ip}) \\ &= \hat{\beta}_0 + \sum_{i \in S} \hat{\alpha}_i y_i \langle h(x), h(x_i) \rangle\end{aligned}\quad (7)$$

Metode SVM menggunakan kernel linier pada Persamaan (6), tetapi kernel nonlinier lebih fleksibel. Kernel nonlinier memetakan variabel p dan x ke dalam ruang dimensi yang lebih tinggi. Pemetaan terjadi secara implisit; polinomial dan variabel lainnya dalam ruang dimensi yang lebih tinggi tidak benar-benar dihitung. Jumlah pengamatan yang sama lebih jarang di ruang dimensi yang lebih tinggi, yang membuatnya lebih mungkin untuk dipisahkan secara linier. Hal ini meningkatkan kinerja algoritma SVM dan membuat batas keputusan kembali ke ruang semula dapat dilakukan (Hastie et al., 2009).

Pilihan yang paling populer untuk kernel nonlinier adalah kernel radial (atau Gaussian), ditentukan sebagai kernel(rbf):

$$K(x_i, x_{i'}) = \exp \left\{ -\gamma \sum_{j=1}^p (x_{ij} - x_{i'j})^2 \right\} \quad (8)$$

di mana $\gamma > 0$ adalah parameter penyetelan tambahan. Ketika pengamatan data uji sangat jauh dari pengamatan data latih, eksponen menjadi sangat negatif, dan $K(x_i, x_{i'})$ mendekati nol. Dalam hal ini, pengamatan data latih yang jauh dari pengamatan data uji hampir tidak berpengaruh pada keputusan bagaimana mengklasifikasikan pengamatan data uji. Parameter mengatur seberapa dekat observasi yang harus dilakukan untuk melanjutkan keputusan klasifikasi. Kernel ini lebih fleksibel daripada kernel linier.

Kernel polinomial derajat d , disebutkan sebagai kernel(poly) degree(d), yaitu:

$$K(x_i, x_{i'}) = \left(\beta_0 + \gamma \sum_{j=1}^p x_{ij} x_{i'j} \right)^d \quad (9)$$

di mana $\gamma > 0$ dan β_0 adalah parameter penyetelan (tuning) tambahan. Menggunakan kernel ini sama dengan menambahkan pangkat polinomial dari variabel x , seperti dalam regresi polinomial. Namun, di sini variabel tambahan tidak dihitung secara eksplisit, hanya tersirat dalam penggunaan kernel. Standarnya adalah derajat (3). Nilai d yang lebih besar membuat model lebih kompleks, tetapi seringkali $d = 2$ atau $d = 3$ sudah cukup.

Pilihan kernel lainnya adalah kernel sigmoid, disebut sebagai kernel(sigmoid):

$$K(x_i, x_{i'}) = \tanh \left(\beta_0 + \gamma \sum_{j=1}^p x_{ij} x_{i'j} \right) \quad (10)$$

di mana $\gamma > 0$ dan β_0 adalah parameter penyetelan (tuning) tambahan. Kernel ini tidak umum digunakan seperti kernel yang disebutkan sebelumnya, sebagian karena beberapa sifat teoritis yang tidak diinginkan (tidak pasti positif untuk beberapa pengaturan parameter) (Lin & Lin, 2003).

BAB II

Optimalisasi Deteksi Gaya Belajar di LMS: Analisis Komparatif Algoritma *Machine Learning* dalam Model Felder-Silverman

Abstrak

Merancang metode pengajaran yang efektif yang sesuai dengan kebutuhan siswa merupakan langkah penting dalam proses belajar mengajar. Salah satu faktor yang dapat dipertimbangkan saat merancang metode pengajaran adalah mengetahui gaya belajar siswa. Identifikasi gaya belajar dimungkinkan dengan mengamati perilaku siswa yang tercatat dalam *Learning Management System* (LMS). Namun, fitur yang tersedia di LMS biasanya terbatas pada fungsi umum seperti pengiriman tugas, ujian online, dan pengaturan kelas, sedangkan untuk mendeteksi gaya belajar, diperlukan fitur khusus, seperti waktu yang dibutuhkan siswa untuk menyelesaikan tugas, berapa kali siswa mengunjungi konten siswaan tertentu, atau berapa banyak waktu yang dihabiskan siswa dalam konten, sehingga sulit untuk mendeteksi gaya belajar siswa secara langsung. Pada bagian ini, akan disusun kerangka kerja dengan memodifikasi fitur yang tersedia di LMS agar sesuai dengan fitur yang diperlukan untuk mendeteksi gaya belajar siswa secara otomatis. Setelah itu dilakukan pemetaan perilaku online mahasiswa ke dimensi FSLSM dengan pendekatan berbasis literatur, kemudian dilakukan klasifikasi menggunakan beberapa Teknik *machine learning*. Data LMS yang digunakan adalah LMS dari Sistem Pembelajaran *Online* Indonesia (SPADA), yang mencatat perilaku belajar daring 109.807 mahasiswa dari berbagai perguruan tinggi di Indonesia. Hasil penelitian menghasilkan 7 fitur baru yang diperlukan untuk mendeteksi model gaya belajar Felder Silverman, dan Teknik *machine learning* yang menunjukkan akurasi tertinggi dalam klasifikasi gaya belajar adalah *Decision Tree*.

Kata Kunci : Deteksi Otomatis, Felder Silverman, Gaya Belajar, *Learning Management System*, *Machine Learning*, Perilaku *Online*

2.1. Pendahuluan

Seiring dengan kemajuan teknologi, pembelajaran mesin telah menjadi solusi efektif dalam mendeteksi gaya belajar siswa (Lwande et al., 2021; Graf et al., 2008). Algoritma pembelajaran mesin mampu menganalisis data dalam jumlah besar dan mengidentifikasi pola tersembunyi dalam perilaku belajar siswa, sehingga memungkinkan deteksi otomatis yang lebih akurat dan efisien (Abdullah, 2015; Rajper et al., 2016; Ngatirin dan Zainol, 2021). Salah satu model gaya belajar yang banyak digunakan dalam konteks ini adalah Felder-Silverman Learning Style Model (FSLSM) (Feldman et al., 2015). FSLSM mengklasifikasikan gaya belajar siswa ke dalam empat dimensi utama, yaitu aktif-

reflektif, sensing-intuitif, visual-verbal, dan sequential-global. Model ini menawarkan pemahaman yang lebih komprehensif terhadap cara siswa menerima dan mengolah informasi, sehingga memungkinkan personalisasi pembelajaran yang lebih efektif dan sesuai dengan kebutuhan individu (Graf, 2007; Alkhuraji et al., 2011).

Di Indonesia, LMS-SPADA (Sistem Pembelajaran Daring Indonesia) menjadi platform pembelajaran daring nasional yang digunakan oleh berbagai perguruan tinggi dan institusi pendidikan untuk memfasilitasi proses pembelajaran jarak jauh. LMS-SPADA dikembangkan oleh Kementerian Pendidikan, Kebudayaan, Riset, dan Teknologi (Kemendikbudristek) sebagai bagian dari inisiatif untuk memperluas akses pendidikan tinggi dan meningkatkan kualitas pembelajaran daring di seluruh negeri. Melalui LMS-SPADA, mahasiswa dapat mengakses berbagai materi kuliah, mengikuti diskusi online, mengerjakan tugas, dan mengikuti ujian secara daring. Platform ini memiliki jangkauan luas dan melibatkan mahasiswa dari berbagai latar belakang pendidikan, menjadikannya sumber data yang potensial untuk penelitian dalam skala besar.

Namun, meskipun LMS-PADA memiliki fitur yang cukup lengkap dalam mendukung aktivitas pembelajaran, fitur-fitur ini belum sepenuhnya memadai untuk mendeteksi gaya belajar mahasiswa secara otomatis berdasarkan FSLSM. Data yang dihasilkan dari aktivitas mahasiswa dalam LMS-SPADA, seperti durasi akses materi, partisipasi diskusi, dan hasil evaluasi, cenderung terfragmentasi dan tidak langsung merepresentasikan indikator gaya belajar yang sesuai dengan FSLSM. Hal ini menciptakan tantangan dalam proses deteksi gaya belajar yang akurat.

Pada bagian ini, keterbatasan fitur dalam LMS SPADA dalam mendeteksi gaya belajar berdasarkan FSLSM akan diidentifikasi. Salah satu solusi yang diusulkan adalah penerapan agregasi fitur, yaitu pendekatan yang menggabungkan berbagai data aktivitas mahasiswa menjadi indikator yang lebih relevan dengan dimensi FSLSM. Melalui proses ini, data yang sebelumnya tersebar dan tidak terstruktur dapat diolah menjadi sejumlah fitur baru yang lebih representatif. Pendekatan ini diharapkan dapat meningkatkan akurasi deteksi tanpa memerlukan perubahan besar pada struktur dan sistem LMS SPADA itu sendiri.

Selain itu akan dilakukan analisis komparasi dari Support Vector Machine (SVM) dengan teknik *machine learning* lainnya. Penelitian sebelumnya menunjukkan bahwa SVM sering kali menghasilkan akurasi yang lebih tinggi dibandingkan algoritma *machine learning* lainnya, terutama pada data dengan jumlah sampel yang kecil dan berasal dari subjek yang homogen, seperti mahasiswa dari jurusan atau program studi yang sama (Amir et al., 2016; Mehenaoui et al., 2022). SVM mampu mengidentifikasi pola dengan lebih baik dalam data yang memiliki dimensi tinggi dan keterbatasan jumlah sampel, menjadikannya pilihan yang tepat untuk studi dengan cakupan terbatas. Namun,

dalam konteks data yang lebih besar dan heterogen, seperti yang dihasilkan dari LMS-SPADA yang melibatkan mahasiswa dari berbagai jurusan dan institusi, belum dilakukan komparasi efektivitas SVM dengan algoritma lain dalam mendeteksi gaya belajar. Oleh karena itu, akan dilakukan eksplorasi performa SVM pada skala data yang lebih luas, serta membandingkannya dengan algoritma lain seperti *Decision Tree*, *Naive Bayes*, dan *K-Nearest Neighbor* (KNN), guna mengidentifikasi metode yang paling efektif untuk diterapkan dalam sistem pembelajaran daring berskala nasional.

2.2. Metode

Data yang digunakan pada penelitian ini diambil dari LMS-SPADA. SPADA Indonesia merupakan program Direktorat Jenderal Pembelajaran dan Kemahasiswaan Kementerian Riset, Teknologi dan Pendidikan Tinggi (Kemristek Dikti) yang bertujuan untuk meningkatkan pemerataan akses terhadap pembelajaran yang bermutu di Perguruan Tinggi. Data LMS-SPADA yang diambil merupakan data log dari system LMS-SPADA pada bulan Desember 2019 yang terdiri dari 110.210 mahasiswa dari 61 Perguruan Tinggi dan mengikuti 42 matakuliah. LMS-SPADA dapat diakses pada laman <https://lmsspada.kemdikbud.go.id/>.

Tahapan analisis yang dilakukan untuk mendeteksi gaya belajar siswa secara otomatis adalah sebagai berikut:

1. Mengidentifikasi fitur-fitur yang tersedia pada LMS-SPADA;
2. Melakukan ekstraksi fitur LMS-SPADA yang sesuai dengan indikator masing-masing dimensi dalam model FSLSM. Fitur LMS-SPADA dipilih sesuai dengan indikator model FSLSM sebagai fitur dalam model klasifier SVM. Selain itu, indikator model FSLSM juga dapat diperoleh dari agregasi beberapa atribut LMS-SPADA, sehingga menghasilkan fitur sintesis sebagai fitur dalam model klasifier SVM;
3. Melakukan pemetaan perilaku online berdasarkan 4 dimensi dari FSLSM;
4. Melakukan pelabelan (*labelling process*) pada setiap sampel (*observation*) berdasarkan hasil pemetaan perilaku online;
5. Melakukan klasifikasi gaya belajar menggunakan SVM;
6. Membandingkan akurasi SVM dengan Decision Tree, Naïve Bayes dan KNN.

2.3. Hasil Analisis

2.3.1. Data collection

Fitur-fitur yang tersedia pada LMS SPADA dapat dilihat pada tabel 2.1. berikut:

Tabel 2.1 Fitur yang tersedia pada LMS-SPADA

No	Fitur	Keterangan
1.	<i>Content Complete</i>	Jumlah konten pembelajaran yang telah diselesaikan oleh siswa.
2.	<i>Content Required</i>	Jumlah konten pembelajaran yang diwajibkan atau harus diakses oleh siswa.
3.	<i>Quiz Complete</i>	Jumlah kuis yang telah diselesaikan oleh siswa.
4.	<i>Total Quiz Attempt</i>	Total percobaan atau usaha siswa dalam mengerjakan kuis, termasuk pengulangan
5.	<i>Discussion Post Created</i>	Jumlah postingan yang dibuat oleh siswa dalam forum diskusi
6.	<i>Discussion Post Replies</i>	Jumlah balasan yang diberikan oleh siswa dalam forum diskusi, baik untuk postingan sendiri maupun orang lain.
7.	<i>Discussion Post Read</i>	Jumlah postingan di forum diskusi yang telah dibaca oleh siswa.
8.	<i>Number of Assignment Submission</i>	Jumlah tugas yang telah diajukan atau dikumpulkan oleh siswa.
9.	<i>Total Time Spent in Content</i>	Total waktu yang dihabiskan oleh siswa untuk mengakses konten pembelajaran di LMS.

Sumber: data log LMS-SPADA

2.3.2. Data Preprocessing

Tahapan *pre-processing* data merupakan langkah krusial dalam pengembangan model deteksi gaya belajar mahasiswa berbasis Felder-Silverman Learning Style Model (FSLSM) menggunakan data dari LMS-SPADA. Pre-processing berperan dalam memastikan bahwa data yang digunakan memiliki kualitas dan representasi yang sesuai dengan indikator yang dibutuhkan untuk mendeteksi setiap dimensi FSLSM. Dalam konteks ini, proses pre-processing terdiri dari tiga tahapan utama, yaitu identifikasi fitur, agregasi fitur, dan pelabelan data (labelling).

2.3.2.1. Ekstraksi langsung dari fitur LMS.

Data diekstraksi dari LMS SPADA dengan melakukan pengambilan data secara langsung. Data diambil berdasarkan asumsi bahwa fitur yang diambil berkontribusi dalam menentukan gaya belajar dari pelajar. Hasil ekstraksi fitur dapat dilihat pada Tabel berikut:

Tabel 2.2 Ekstraksi fitur LMS-SPADA

Fitur	Keterangan
<i>Quiz Revisions</i> (X_1)	Fitur diambil dari kolom <i>Total Quiz Attempts</i> dalam data LMS SPADA.
<i>Exercise Visit</i> (X_2)	Fitur diambil dari kolom <i>Number Of Assignment Submissions</i> dalam data LMS SPADA
<i>Content Visit</i> (X_3)	Fitur diambil dari kolom <i>Content Completed</i> dalam data LMS SPADA
<i>Content Stay</i> (X_4)	Fitur diambil dari kolom <i>Time spent in content</i> dalam data LMS SPADA
<i>Forums Visit</i> (X_5)	Fitur diambil dari kolom <i>Discussion Post Read</i> dalam data LMS SPADA
<i>Forum Post</i> (X_6)	Fitur diambil dari kolom <i>Discussion Post Created</i> dalam data LMS SPADA

2.3.2.2. Sintesis fitur dari beberapa atribut LMS

Selanjutnya, melakukan agregasi pada beberapa atribut LMS SPADA, sehingga menghasilkan fitur sintesis yang dijadikan sebagai fitur dalam model klasifier SVM. Hasil agregasi beberapa atribut dapat dilihat pada Tabel berikut:

Tabel 2.3 Agregasi Fitur LMS-SPADA

Fitur	Keterangan
<i>Forum Stay</i> (X_7)	Fitur ini dibentuk dari 3 fitur yang tersedia pada LMS, yaitu <i>Discussion Post Read</i>, <i>Discussion Post Replies</i> dan <i>Discussion Post Created</i>. Nilainya diperoleh dengan langkah-langkah berikut: 1. Hitung rata-rata dari <i>Discussions Post Read</i> (R): Jika pelajar memiliki nilai <i>Discussions Post Read</i> di

Lanjutan Tabel 2.3

Fitur	Keterangan
	atas rata-rata, maka nilai R= 1; jika di bawah rata-rata, nilai R = 0. 2. Hitung rata-rata dari <i>Discussions Post Replies</i> (Re): Jika pelajar memiliki nilai <i>Discussions Post Replies</i> di atas rata-rata, maka nilai Re = 1; jika di bawah rata-rata, nilai Re = 0. 3. Hitung rata-rata dari <i>Discussions Post Created</i> (C): Jika pelajar memiliki nilai <i>Discussions Post Created</i> di atas rata-rata, maka nilai C = 1; jika di bawah, nilai C= 0. 4. Totalkan nilai Forum Stay (X_7): $X_7 = R + Re + C$ Dengan nilai akhir X_7 memiliki kemungkinan 0, 1, 2, atau 3, yang menunjukkan tingkat aktivitas di forum, dari 0 sebagai nilai paling rendah hingga 3 sebagai nilai paling tinggi .
Question Graphics Poin (X_8)	Fitur ini dibentuk dari <i>Time Spent in Content</i>, <i>Content Required</i> dan <i>Quiz Complete</i>. Nilainya diperoleh dengan langkah-langkah sebagai berikut: 1. Kelompokkan kelas berdasarkan waktu rata-rata pada materi pembelajaran: - Hitung rata-rata Time per Content: $\frac{\text{Time spent in Content}}{\text{Time Required}}$ - Jika rata-rata waktu di atas 20 menit, kelas tersebut diasumsikan menggunakan materi visual/gambar/video. 2. Penilaian berdasarkan materi pembelajaran: - Jika pelajar menghabiskan waktu di atas rata-rata pada materi visual, beri 100 poin; jika di bawah rata-rata, beri 50 poin. 3. Penilaian berdasarkan kuis yang diselesaikan: - Bagi pelajar dalam 4 kuartil berdasarkan jumlah Qiuз Complete: • Kuartil 1 : 25 poin • Kuartil 2 : 50 poin

Lanjutan Tabel 2.3

Fitur	Keterangan
	• Kuartil 3 : 75 poin • Kuartil 4 : 100 poin
	4. Perhitungan Akhir:
	$X_8 = \frac{Poin\ Materi + Poin\ Kuis}{2}$
	Rentang nilai antara 0 sampai 100 poin
Question Text Poin (X_9)	Fitur ini dibentuk dari <i>Time Spent in Content</i>, <i>Content Required</i> dan <i>Quiz Complete</i>. Nilainya diperoleh dengan langkah-langkah sebagai berikut: 1. Kelompokkan kelas berdasarkan waktu rata-rata pada materi pembelajaran: - Hitung rata-rata Time per Content: $\frac{Time\ spent\ in\ Content}{Time\ Required}$ - Jika rata-rata waktu di bawah 20 menit, kelas tersebut diasumsikan menggunakan materi pembelajaran verbal/teks. 2. Penilaian berdasarkan materi pembelajaran: - Jika pelajar menghabiskan waktu di atas rata-rata pada materi visual, beri 100 poin; jika di bawah rata-rata, beri 50 poin. 3. Penilaian berdasarkan kuis yang diselesaikan: - Bagi pelajar dalam 4 kuartil berdasarkan jumlah Qiuiz Complete: • Kuartil 1 : 25 poin • Kuartil 2 : 50 poin • Kuartil 3 : 75 poin • Kuartil 4 : 100 poin 4. Perhitungan Akhir: $X_9 = \frac{Poin\ Materi + Poin\ Kuis}{2}$ Rentang nilai antara 0 sampai 100 poin
Question Facts Poin (X_{10})	Fitur ini dibentuk dari fitur <i>Quiz Completed</i> dan <i>Number of Assignment Submission</i>. Nilainya diperoleh dengan langkah-langkah sebagai berikut: 1. Penilaian berdasarkan kuis yang diselesaikan:

Lanjutan Tabel 2.3

Fitur	Keterangan
	- Bagi pelajar dalam 4 kuartil berdasarkan jumlah QiuZ Complete: • Kuartil 1 : 25 poin • Kuartil 2 : 50 poin • Kuartil 3 : 75 poin • Kuartil 4 : 100 poin 2. Penilaian berdasarkan jumlah pengajuan tugas: - Hitung rata-rata <i>Number of Assigment Submission</i> dalam setiap kelas, Jika jumlah pengajuan tugas pelajar di atas rata-rata, maka beri 100 poin; jika di bawah rata-rata, beri 50 poin. 3. Perhitungan Akhir: $X_{10} = \frac{\text{Poin Kuis} + \text{Poin Pengajuan Tugas}}{2}$ Rentang nilai antara 0 sampai 100 poin
Question Concepts Poin (X_{11})	Fitur ini dibentuk dari fitur <i>Quiz Completed</i> dan <i>Content Completed</i> dan <i>Time Spent in Content</i>. Nilainya diperoleh dengan langkah-langkah sebagai berikut: 1. Penilaian berdasarkan kuis yang diselesaikan: - Bagi pelajar dalam 4 kuartil berdasarkan jumlah QiuZ Complete: • Kuartil 1 : 25 poin • Kuartil 2 : 50 poin • Kuartil 3 : 75 poin • Kuartil 4 : 100 poin 2. Penilaian berdasarkan materi pembelajaran yang diselesaikan: - Hitung rata-rata <i>Content Completed</i> dalam setiap kelas, Jika jumlah materi yang diselesaikan oleh pelajar di atas rata-rata, maka beri 100 poin; jika di bawah rata-rata, beri 50 poin. 3. Penilaian berdasarkan waktu yang dihabiskan dalam materi pembelajaran: - Bagi pelajar dalam 4 kuartil berdasarkan <i>Time Spent in Content</i>: • Kuartil 1 : 25 poin

Lanjutan Tabel 2.3

Fitur	Keterangan
	• Kuartil 2 : 50 poin • Kuartil 3 : 75 poin • Kuartil 4 : 100 poin
	4. Perhitungan Akhir: $X_{11} = \frac{\text{Poin Kuis} + \text{Poin Materi} + \text{Poin Waktu}}{3}$ Rentang nilai antara 0 sampai 100 poin
Question Detail Poin (X_{12})	Fitur ini dibentuk dari fitur <i>Quiz Completed</i> dan <i>Discussion Post Replay</i>. Nilainya diperoleh dengan langkah-langkah sebagai berikut: 1. Penilaian berdasarkan kuis yang diselesaikan: - Bagi pelajar dalam 4 kuartil berdasarkan jumlah Qiuiz Complete: • Kuartil 1 : 25 poin • Kuartil 2 : 50 poin • Kuartil 3 : 75 poin • Kuartil 4 : 100 poin 2. Penilaian berdasarkan jumlah balasan forum: - Hitung rata-rata <i>Discussion Post Replay</i> dalam setiap kelas, Jika jumlah balasan forum di atas rata-rata, maka beri 100 poin; jika di bawah rata-rata, beri 50 poin. 3. Perhitungan Akhir: $X_{12} = \frac{\text{Poin Kuis} + \text{Poin Balasan Forum}}{2}$ Rentang nilai antara 0 sampai 100 poin
Question Overview Poin (X_{13})	Fitur ini dibentuk dari fitur <i>Quiz Completed</i> dan <i>Discussion Post Read</i>. Nilainya diperoleh dengan langkah-langkah sebagai berikut: 1. Penilaian berdasarkan kuis yang diselesaikan: - Bagi pelajar dalam 4 kuartil berdasarkan jumlah Qiuiz Complete: • Kuartil 1 : 25 poin • Kuartil 2 : 50 poin • Kuartil 3 : 75 poin • Kuartil 4 : 100 poin

Lanjutan Tabel 2.3

Fitur	Keterangan
2.	Penilaian berdasarkan jumlah forum yang dibaca: - Hitung rata-rata <i>Discussion Post Read</i> dalam setiap kelas, Jika jumlah forum yang dibaca di atas rata-rata, maka beri 100 poin; jika di bawah rata-rata, beri 50 poin.
3.	Perhitungan Akhir: $X_{13} = \frac{\text{Poin Kuis} + \text{Poin Forum dibaca}}{2}$ Rentang nilai antara 0 sampai 100 poin

2.3.2.3. Labeling.

Berdasarkan hasil ekstraksi dan agregasi atribut LMS SPADA pada Tabel 2.2. dan Tabel 2.3., diperoleh 13 fitur yang diasumsikan dapat menentukan gaya belajar pelajar. Selanjutnya akan dipetakan berdasarkan FSLSM yang memiliki 4 dimensi.


Tabel 2.4 Pemetaan pola perilaku online FSLSM

LMS Behavior	FSLSM Trend							
	Active	Reflective	Sensing	Intuitive	Visual	Verbal	Sequential	Global
<i>Quiz Revisions (X₁)</i>			+	-				
<i>Exercise Visit (X₂)</i>	+	-	+	-				
<i>Content Visit (X₃)</i>	-	+	-	+	-	+	-	+
<i>Content Stay (X₄)</i>	-	+	-	+	+	-		
<i>Forums Visit (X₅)</i>	-	+			-	+		
<i>Forum Post (X₆)</i>	+	-			-	+		
<i>Forum Stay (X₇)</i>					-	+		
<i>Question Graphics Poin (X₈)</i>					+	-		
<i>Question Text Poin (X₉)</i>					-	+		
<i>Question Facts Poin (X₁₀)</i>			-	+				
<i>Question Concepts Poin (X₁₁)</i>			+	-				
<i>Question Detail Poin (X₁₂)</i>			+	-			+	-
<i>Question Overview Poin (X₁₃)</i>							-	+

Sumber: Liyanage et. al. (2013)

Proses pelabelan dilakukan dengan menentukan ambang batas untuk pola perilaku belajar yang sesuai dengan gaya belajar pada setiap dimensi dalam FSLSM, seperti yang tercantum pada Tabel 2.4. Setelah itu, setiap fitur diberi nilai (- atau +) berdasarkan ambang batas tersebut, lalu total nilai dihitung untuk masing-masing gaya belajar di setiap dimensi FSLSM. Total nilai yang diperoleh kemudian dikelompokkan berdasarkan tanda nilainya.

Pada dimensi Processing, total nilai positif (+) menunjukkan kecenderungan pelajar memiliki gaya belajar *Active*, sedangkan total nilai negatif (-) menunjukkan kecenderungan gaya belajar *Reflective*. Pada dimensi Perception, total nilai positif (+) menunjukkan kecenderungan gaya belajar *Sensing*, sementara total nilai negatif (-) menunjukkan kecenderungan gaya belajar *Intuitive*. Pada dimensi Input, total nilai positif (+) menunjukkan kecenderungan gaya belajar *Visual*, dan total nilai negatif (-) menunjukkan kecenderungan gaya belajar *Verbal*. Pada dimensi Understanding, total nilai positif (+) menunjukkan kecenderungan gaya belajar *Sequential*, sementara total nilai negatif (-) menunjukkan kecenderungan gaya belajar *Global*. Hasil dari proses pelabelan ini dapat dilihat pada Gambar berikut:



Gambar 2.1 Hasil pelabelan data LMS SPADA

Berdasarkan dari Gambar 2.1, mahasiswa dengan gaya belajar *Active* sebanyak 52.027 orang, *Reflective* sebanyak 57.780 orang, *Sensing* sebanyak 78.713 orang, *Intuitive* sebanyak 31.094 orang, *Visual* sebanyak 62.216 orang,

Verbal sebanyak 47.591 orang, *Sequential* sebanyak 36.397 orang, dan *Global* sebanyak 73.410 orang.

2.3.3. Klasifikasi dengan SVM

Eksperimen dilakukan menggunakan *Cross Validation 5-fold*, di mana dataset berjumlah 109807 dibagi menjadi dua bagian, dengan 70% data digunakan sebagai data pelatihan dan 30% sisanya sebagai data uji. Data pelatihan dan data uji dipilih secara acak dan diterapkan dengan teknik holdout. Kernel yang diterapkan adalah Radial Basis Function (RBF) dengan nilai $g=0,10$. Tabel 2.5. menunjukkan akurasi dari pelaksanaan eksperimen pada setiap dimensi.

Tabel 2.5 Akurasi dari Experiment dengan SVM

Dimensi	SVM (%)
<i>Processing</i>	90,9
<i>Perception</i>	81,2
<i>Input</i>	75,9
<i>Understanding</i>	97,3

Sumber: Hasil Olah data menggunakan software Orange

2.3.4. Performance Test: Perbandingan SVM dengan KNN, Naïve Bayes, dan Decision Tree

Agar dapat mengetahui apakah akurasi SVM yang dihasilkan dari experiment ini cukup baik, maka perlu melakukan perbandingan antara algoritma SVM dengan beberapa algoritma klasifikasi *machine learning* yang pernah digunakan oleh peneliti sebelumnya untuk mendeteksi gaya belajar mahasiswa dari perilaku online mereka di LMS.

Tabel 2.6. menunjukkan perbandingan akurasi algoritma SVM dengan algoritma kNN, Naïve Bayes dan Decision Tree.

Tabel 2.6 Perbandingan Akurasi dari Experiment dengan SVM dengan beberapa algoritma *machine learning*

Dimensi	SVM (%)	kNN(%)	NB(%)	Tree(%)
<i>Processing</i>	90,9	94,3	93,6	98,5
<i>Perception</i>	81,2	86,1	88,3	97,7
<i>Input</i>	75,9	84,0	95,2	98,9
<i>Understanding</i>	97,3	100	94,6	100

Sumber: Hasil Olah data menggunakan software Orange

2.4. Pembahasan

Hasil ekstraksi fitur dari LMS-SPADA yang digunakan sebagai variabel dalam proses deteksi gaya belajar mahasiswa berbasis model Felder-Silverman (FSLSM) disajikan pada Tabel 2.2. Ekstraksi fitur ini dilakukan dengan memanfaatkan data aktivitas mahasiswa yang tersedia dalam LMS-SPADA, yang mencerminkan berbagai aspek keterlibatan mereka dalam proses pembelajaran daring. Setiap fitur yang teridentifikasi memiliki keterkaitan dengan indikator FSLSM dan merepresentasikan perilaku belajar mahasiswa dalam berbagai bentuk interaksi dengan sistem.

Quiz Revisions (X_1) merupakan fitur yang diambil dari kolom *Total Quiz Attempts*. Fitur ini menggambarkan seberapa sering mahasiswa mengulang atau memperbaiki kuis yang telah mereka kerjakan, yang dapat menunjukkan preferensi gaya belajar sekuensial atau reflektif, di mana mahasiswa cenderung berusaha memahami materi secara bertahap melalui evaluasi berulang.

Exercise Visit (X_2) berasal dari kolom *Number of Assignment Submissions*, yang mencerminkan jumlah tugas yang diserahkan mahasiswa. Fitur ini mengindikasikan tingkat partisipasi mahasiswa dalam tugas-tugas akademik, yang berkaitan erat dengan keterlibatan aktif dalam proses pembelajaran dan preferensi belajar aktif dalam model FSLSM.

Selanjutnya, *Content Visit* (X_3) adalah fitur yang diambil dari kolom *Content Completed*. Fitur ini menunjukkan seberapa banyak konten pembelajaran yang telah diakses dan diselesaikan oleh mahasiswa. Tingginya jumlah kunjungan konten dapat mencerminkan preferensi belajar sensorik, di mana mahasiswa lebih cenderung menyelesaikan materi secara konkret dan terstruktur.

Content Stay (X_4) diperoleh dari kolom *Time Spent in Content*. Fitur ini merepresentasikan durasi mahasiswa dalam mengakses dan mempelajari konten pembelajaran. Semakin lama mahasiswa menghabiskan waktu dalam satu materi, semakin besar kemungkinan mereka memiliki kecenderungan gaya belajar reflektif dan global, di mana pemahaman yang mendalam lebih diutamakan dibandingkan sekadar menyelesaikan tugas.

Forums Visit (X_5) diambil dari kolom *Discussion Post Read*, yang menunjukkan jumlah diskusi yang telah dibaca mahasiswa dalam forum pembelajaran. Fitur ini mengindikasikan tingkat ketertarikan mahasiswa dalam mencari wawasan tambahan dari diskusi dengan teman sejawat, yang dapat menunjukkan preferensi gaya belajar kolaboratif dan verbal.

Terakhir, *Forum Post* (X_6) berasal dari kolom *Discussion Post Created*. Fitur ini menunjukkan seberapa sering mahasiswa berpartisipasi aktif dalam forum dengan membuat postingan baru. Keterlibatan ini sering dikaitkan dengan gaya belajar aktif, di mana mahasiswa cenderung berkontribusi dan mengajukan pertanyaan dalam lingkungan diskusi daring.

Tabel 2.3 menyajikan proses agregasi fitur dari LMS SPADA yang bertujuan untuk menghasilkan indikator yang lebih representatif dalam mendeteksi gaya belajar mahasiswa berbasis model Felder-Silverman (FSLSM). Proses agregasi ini mengombinasikan berbagai atribut aktivitas mahasiswa dalam LMS untuk menciptakan fitur sintesis yang dapat memperkaya model klasifikasi. Dengan pendekatan ini, fitur-fitur yang sebelumnya terfragmentasi dan memiliki keterbatasan dalam merepresentasikan dimensi FSLSM dapat diolah menjadi fitur yang lebih bermakna dan berkontribusi langsung dalam pengukuran gaya belajar.

Salah satu fitur hasil agregasi adalah *Forum Stay* (X_7), yang merupakan gabungan dari tiga aktivitas utama dalam forum diskusi: *Discussion Post Read*, *Discussion Post Replies*, dan *Discussion Post Created*. Fitur ini mengukur tingkat keterlibatan mahasiswa dalam forum dengan memberikan skor kumulatif berdasarkan seberapa sering mereka membaca, membalas, dan membuat postingan. Dengan nilai yang berkisar antara 0 hingga 3, *Forum Stay* (X_7) memberikan gambaran tingkat partisipasi mahasiswa dalam diskusi, yang relevan untuk mendeteksi kecenderungan gaya belajar aktif atau reflektif.

Fitur *Question Graphics Poin* (X_8) dihasilkan melalui kombinasi data dari *Time Spent in Content*, *Content Required*, dan *Quiz Complete*. Fitur ini bertujuan untuk mengidentifikasi preferensi mahasiswa terhadap materi berbasis visual seperti gambar dan video. Penilaian dilakukan berdasarkan waktu yang dihabiskan dalam mengakses konten visual, serta performa mereka dalam menyelesaikan kuis. Skor akhir berkisar antara 0 hingga 100, mencerminkan sejauh mana mahasiswa menunjukkan kecenderungan terhadap pembelajaran berbasis visual.

Sebaliknya, *Question Text Poin* (X_9) menggunakan metode yang serupa, namun difokuskan pada materi pembelajaran berbasis teks. Dengan menggunakan data yang sama, fitur ini membedakan mahasiswa yang cenderung lebih banyak mengakses materi verbal dibandingkan visual. Kategori ini penting dalam memetakan dimensi visual-verbal dalam FSLSM, di mana mahasiswa dengan skor tinggi pada *Question Text Poin* cenderung memiliki gaya belajar verbal.

Fitur *Question Facts Poin* (X_{10}) dikembangkan dari *Quiz Completed* dan *Number of Assignment Submission*, yang menilai keterlibatan mahasiswa dalam pengajuan tugas dan kuis. Skor ini mencerminkan tingkat ketekunan dan keteraturan mahasiswa dalam menyelesaikan tugas dan evaluasi, yang relevan dengan dimensi sensing-intuitif dalam FSLSM.

Selanjutnya, *Question Concepts Poin* (X_{11}) mengintegrasikan *Quiz Completed*, *Content Completed*, dan *Time Spent in Content*. Fitur ini mengevaluasi mahasiswa berdasarkan jumlah konten yang diselesaikan, waktu yang dihabiskan, dan jumlah kuis yang diselesaikan. Skor ini memberikan indikasi

tentang preferensi mahasiswa dalam memahami konsep secara mendalam atau lebih menyukai pendekatan praktis.

Fitur *Question Detail Poin* (X_{12}) dihasilkan dari *Quiz Completed* dan *Discussion Post Replies*, yang merefleksikan keterlibatan mahasiswa dalam memberikan tanggapan terhadap diskusi akademik. Fitur ini mengukur sejauh mana mahasiswa mendalami materi dan berpartisipasi dalam forum dengan memberikan umpan balik atau tanggapan terhadap mahasiswa lain.

Terakhir, *Question Overview Poin* (X_{13}) dibentuk dari *Quiz Completed* dan *Discussion Post Read*, yang berfokus pada pemahaman umum mahasiswa terhadap materi. Fitur ini menggambarkan kebiasaan mahasiswa dalam membaca forum dan mengerjakan kuis, yang menjadi indikator kecenderungan gaya belajar global atau sekuensial.

Pada Tabel 2.4. terlihat bahwa pada dimensi *Perception*, *Tree* memiliki akurasi tertinggi sebesar 97,7%, diikuti oleh Naive Bayes (NB) dengan 88,3%, kemudian kNN dengan 86,1%, dan terakhir SVM dengan 81,2%. SVM menempati posisi keempat atau terendah di antara keempat algoritma pada dimensi ini. Pada dimensi *Processing*, *Tree* kembali menunjukkan akurasi tertinggi sebesar 98,5%, diikuti oleh kNN dengan 94,3%, NB dengan 93,6%, dan SVM dengan 90,9%. SVM kembali menempati posisi keempat atau terendah dibandingkan algoritma lain pada dimensi ini. Pada dimensi *Input*, *Tree* kembali berada di posisi tertinggi dengan akurasi 98,9%, diikuti oleh NB dengan 95,2%, kNN dengan 84,0%, dan SVM dengan 75,9%. Di sini, SVM juga menempati posisi keempat atau terendah. Pada dimensi *Understanding*, *Tree* dan kNN mencapai akurasi sempurna dengan 100%, diikuti oleh SVM dengan 97,3%, dan NB dengan 94,6%. Pada dimensi ini, SVM berada di peringkat ketiga, lebih tinggi dari NB tetapi di bawah *Tree* dan kNN.

Secara keseluruhan, SVM berada di posisi paling rendah di tiga dimensi pertama (*Perception*, *Processing*, *Input*), menunjukkan kinerja yang kurang optimal dibandingkan ketiga algoritma lainnya dalam klasifikasi data pada learning management system. Namun, pada dimensi *Understanding*, SVM berada di peringkat ketiga dengan akurasi yang hampir sempurna (97,3%), lebih tinggi dari NB tetapi tetap lebih rendah dibandingkan *Tree* dan kNN yang mencapai akurasi 100%. Posisi SVM dalam klasifikasi ini menunjukkan bahwa, meskipun dapat digunakan untuk klasifikasi gaya belajar mahasiswa, akurasinya tertinggal dibandingkan *Tree*, kNN, dan NB, terutama pada dimensi *Perception*, *Processing*, dan *Input*.

Hasil analisis ini bertentangan dengan eksperimen yang dilakukan oleh Amir et al. (2016) yang membandingkan SVM dengan Naïve Bayes untuk mendeteksi gaya belajar 200 mahasiswa *computer science*. Pada eksperimen ini, SVM menunjukkan akurasi yang lebih tinggi dari Naïve Bayes. Penelitian lain yang membandingkan beberapa teknik *machine learning* (LR, LDA, kNN, CART, NB

dan SVM) juga menunjukkan akurasi yang paling tinggi adalah SVM (Mehenaoui et al., 2022).

2.5. Kesimpulan

LSM SPADA tidak menyediakan semua fitur yang dibutuhkan untuk melakukan deteksi otomatis gaya belajar FSLSM, namun fitur-fitur yang tersedia dapat dimodifikasi untuk mendapatkan fitur-fitur yang dibutuhkan FSLSM. Terdapat 6 fitur yang dapat diambil langsung dari LMS. SPADA, sedangkan 7 fitur yang lain dibentuk dari modifikasi beberapa fitur yang tersedia di LSM SPADA.

SVM tidak berhasil menunjukkan akurasi yang tinggi dalam mendeteksi gaya belajar siswa melalui perilaku online pada LMS SPADA. Perbandingan antara SVM dengan beberapa teknik machine learning untuk klasifikasi menunjukkan kinerja SVM kurang optimal pada setiap dimensi, sehingga perlu melanjutkan penelitian ini dengan meninjau ulang faktor-faktor yang menyebabkan SVM tidak berhasil pada data LMS SPADA ini.

2.6. Daftar Pustaka

- Abdullah, M. (2015). Learning Style Classification Based on Student's Behavior in Moodle Learning Management System. *Transaction on Machine Learning and Artificial Intelligence*. vol. 3. no. 1. pp. 28–40. doi:10.14738/TMLAI.31.868
- Ahmad, N., Tasir, Z., Kasim, J., and Sahat, H. (2013). Automatic Detection of Learning Styles in Learning Management Systems by Using Literature-based Method. *Procedia - Social and Behavioral Sciences*. vol. 103. pp. 181–189. doi: 10.1016/j.sbspro.2013.10.324.
- Alkhuraji, S., Cheetham, B., and Bamasak, O., Dynamic Adaptive Mechanism in Learning Management System Based on Learning Styles. (2011). 2011 IEEE 11th International Conference on Advanced Learning Technologies. pp. 215–217. doi: 10.1109/ICALT.2011.69.
- Amir, E. S., Sumadyo, M., Sensuse, D. I., Sucahyo, Y. G., and Santoso, H. B. (2016). "Automatic detection of learning styles in learning management system by using literature-based method and support vector machine. (2016). 2016 International Conference on Advanced Computer Science and Information Systems (ICACSIS). pp. 141–144. doi: 10.1109/ICACSIS.2016.7872770.
- Dung, P. Q., and Florea, A. M. (2012). A literature-based method to automatically detect learning styles in learning management systems. *Proceedings of the 2nd International Conference on Web Intelligence. Mining and Semantics*, in

- WIMS '12. Craiova. Romania: Association for Computing Machinery. pp. 1–7. doi: 10.1145/2254129.2254186.
- Feldman, J., Monteserin, A., and Amandi, A. (2015). Automatic detection of learning styles: state of the art. *Artif Intell Rev.* vol. 44. no. 2. pp. 157–186, doi: 10.1007/s10462-014-9422-6.
- Graf, S. (2007). *Adaptivity in Learning Management Systems Focussing On Learning Styles*. Vienna University of Technology. 9801086 Neulinggasse 22/12A 1030 Vienna
- Graf, S., Kinshuk, and Liu, T.C. (2008). Identifying Learning Styles in Learning Management Systems by Using Indications from Students' Behaviour. Eighth IEEE International Conference on Advanced Learning Technologies. pp. 482–486. doi: 10.1109/ICALT.2008.84.
- Li, L. X., and Abdul Rahman, S. S. (2018). Students' learning style detection using tree augmented naive Bayes. *Royal Society Open Science.* vol. 5. no. 7. p. 172108. doi: 10.1098/rsos.172108.
- Liyanage, P., Gunawardena, L. and Hirakawa, M. (2016). Detecting Learning Styles in Learning Management Systems Using Data Mining. *Journal of Information Processing.* vol. 24, pp. 740–749. doi: 10.2197/ipsjip.24.740.
- Lwande, C., Muchemi, L. and Oboko R. (2021). Identifying learning styles and cognitive traits in a learning management system. *Heliyon*, vol. 7, no. 8, p. e07701. doi: 10.1016/j.heliyon.2021.e07701.
- Mahnane, L., and Hafidi, M. (2021). Automatic detection of learning styles based on dynamic Bayesian network in adaptive e-learning system. *International Journal of Innovation and Learning*. Accessed: Apr. 20, 2021.
- Mehenaoui Z., Yacine L., Layachi Z.,(2022). Learning Behavior Analysis to Identify Learner's Learning Style based on Machine Learning Techniques. *JUCS - Journal of Universal Computer Science.* 28. 1193-1220. 10.3897/jucs.81518.
- Ngatirin, N. R., and Zainol, Z. (2021). Automatic Detection of Learning Styles: A Decade Review on Data-driven Approaches. *J. Phys.: Conf. Ser.* vol. 1997. no. 1. p. 012001. doi: 10.1088/1742-6596/1997/1/012001.
- Özpolat, E., and Akar, G. B. (2009). Automatic detection of learning styles for an e-learning system. *Computers & Education.* vol. 53. no. 2, pp. 355–367. doi: 10.1016/j.compedu.2009.02.018.
- Rajper, S., Shaikh, N. A., and Mallah, G. A. (2016). Automatic Detection of Learning Styles on Learning Management Systems using Data Mining Technique. *Indian Journal of Science and Technology*.
- Rasheed, F. and Wahid, A. (2021). Learning style detection in E-learning systems using machine learning techniques. *Expert Systems with Applications*, vol. 174, p. 114774. doi: 10.1016/j.eswa.2021.114774.

- Siegel, H. (2010). Introduction: Philosophy of Education and Philosophy. doi: 10.1093/oxfordhb/9780195312881.003.0001.
- Stantchev, V., Colomo-Palacios, R., Soto-Acosta, P., and Misra, S. (2014). Learning management systems and cloud file hosting services: A study on students' acceptance. *Computers in Human Behavior*. vol. 31. pp. 612–619. doi: 10.1016/j.chb.2013.07.002.
- Yang, L., Hanneke, S., and Carbonell, J. (2013). A Theory of Transfer Learning with Applications to Active Learning. *Machine Learning*. vol. 90. doi: 10.1007/s10994-012-5310-y.